

ỨNG DỤNG PARTICLE FILTER TRONG ƯỚC LƯỢNG MỨC ĐỘ HƯ HỎNG VÀ DỰ ĐOÁN TUỔI THỌ CỦA HỆ THỐNG CÓ XÉT ĐẾN HƯ HỎNG CỦA THIẾT BỊ GIÁM SÁT

PARTICLE FILTER FOR CONDITION ESTIMATION AND LIFETIME PROGNOSIS OF MANUFACTURING SYSTEM CONSIDERING DEGRADATION OF CONDITION MONITORING DEVICE

Dinh Đức Hạnh*, Tào Quang Bằng

Trường Đại học Bách khoa - Đại học Đà Nẵng, Việt Nam¹

*Tác giả liên hệ / Corresponding author: ddhanh@dut.udn.vn

(Nhận bài / Received: 22/01/2024; Sửa bài / Revised: 01/4/2024; Chấp nhận đăng / Accepted: 17/4/2024)

Tóm tắt - Bảo trì dự đoán là một hướng đi mới nhằm đảm bảo hiệu quả hoạt động của hệ thống sản xuất. Đối với bảo trì dự đoán, giám sát tình trạng hư hỏng của thiết bị có vai trò quan trọng trong lập kế hoạch bảo trì thiết bị. Tuy nhiên, các cảm biến dùng để giám sát tình trạng thiết bị cũng hư hỏng theo thời gian. Khi cảm biến hư hỏng, nó cung cấp thông tin sai lệch về mức độ hư hỏng và dự đoán tuổi thọ của thiết bị. Hậu quả là nó dẫn đến ra quyết định bảo trì không chính xác. Để giải quyết vấn đề này, Particle filter được ứng dụng để ước lượng tình trạng hư hỏng và dự đoán tuổi thọ dựa vào dữ liệu được đo bởi cảm biến. Phương pháp này hoạt động như một bộ lọc Bayesian, sử dụng lý thuyết Bayesian để ước lượng trạng thái hệ thống. Một số ví dụ được thực hiện để chứng minh tính hiệu quả của phương pháp này. Kết quả cho thấy Particle filter nâng cao đáng kể tính chính xác của ước lượng trạng thái của hệ thống.

Từ khóa - Giám sát tình trạng máy; bảo trì dự đoán; dự đoán tuổi thọ; hư hỏng cảm biến; particle filter

1. Đặt vấn đề

Thiết bị sản xuất dần xuống cấp và hư hỏng theo thời gian sử dụng. Sự hư hỏng của thiết bị có thể gây ra những thiệt hại lớn về kinh tế, thậm chí làm mất an toàn lao động. Do đó, bảo trì đóng vai trò quan trọng trong đảm bảo hệ thống sản xuất có độ tin cậy, khả năng sẵn sàng và năng suất cao. Những năm gần đây, các nhà nghiên cứu đã đề xuất nhiều chính sách bảo trì khác nhau, trong đó bảo trì dự đoán (Predictive maintenance – PdM) là nổi bật hơn cả [1-2]. PdM thực hiện kiểm tra mức độ hư hỏng hiện tại của thiết bị, dựa trên đó tiến hành dự đoán thời điểm hư hỏng xảy ra. Do đó, PdM giúp lập kế hoạch bảo trì đúng thời điểm, chỉ ngay trước khi hư hỏng xảy ra. Kết quả là nó có thể giảm chi phí bảo trì cũng như thời gian dừng máy. PdM bao gồm 3 quá trình: (1) kiểm tra tình trạng thiết bị, (2) mô hình hoá quá trình hư hỏng và dự đoán tuổi thọ, và (3) lập kế hoạch bảo trì [3-4]. Tình trạng hư hỏng của thiết bị có thể quan sát được thông qua hoạt động kiểm tra các chỉ số như dao động máy, nhiệt độ, độ mòn, hiệu suất, v.v. Ngày nay, các máy móc hiện đại thường được trang bị các cảm biến để giám sát tình trạng hư hỏng của thiết bị theo thời gian thực.

Tuy nhiên, cũng giống như thiết bị chính, cảm biến cũng bị hư hỏng dần theo thời gian sử dụng [5]. Sự hư hỏng của

Abstract - Predictive maintenance is a promising maintenance approach for guaranteeing the system performances. In predictive maintenance, condition monitoring plays an important role since it indicates current degradation state of the system, which supports life time prognosis and maintenance decision making. However, the condition monitoring device also deteriorates with time and usage. The degradation of condition monitoring device leads to inaccurate system condition monitoring data and lifetime prognosis. This consequently leads to non-appreciate maintenance decision making. To address this issue, this paper applies Particle filter for estimating the degradation level and predicting Remaining useful life (RUL) of the system based on observed information. This method operates as a Bayesian filter, employing Bayesian theory for state estimation. Several examples are conducted to show the feasibility and effectiveness of the proposed method. The obtain result show that Particle filter can increase the accuracy of system state estimation significantly.

Key words - Condition monitoring; predictive maintenance; lifetime prognosis; sensor degradation; particle filter

cảm biến dẫn đến thông tin không chính xác về tình trạng hư hỏng của thiết bị chính. Do đó, việc lập kế hoạch bảo trì cho thiết bị dựa hoàn toàn vào những thông tin do cảm biến cung cấp sẽ không chính xác. Tuy nhiên, hiện tại có rất ít nghiên cứu về ước lượng mức độ hư hỏng của thiết bị có xét đến sự hư hỏng của cảm biến. Gần đây, Liu và cộng sự xét đến sự hư hỏng của cảm biến trong mô hình hoá quá trình hư hỏng của thiết bị [6]. Các tác giả áp dụng Kalman filter để ước lượng mức độ hư hỏng của thiết bị chính và của cảm biến dựa trên dữ liệu đo bởi cảm biến. Biết rằng dữ liệu đo bởi cảm biến bị nhiễu bởi sự hư hỏng của bản thân cảm biến. Lưu ý rằng, khi hệ thống là tuyến tính và nhiễu có kiểu phân bố chuẩn thì Kalman filter là phương pháp tối ưu để ước lượng trạng thái của hệ thống. Tuy nhiên, Kalman filter chỉ có thể áp dụng khi mô hình trạng thái là tuyến tính và nhiễu có kiểu phân bố chuẩn [6]. Khác với Kalman filter, Particle filter có khả năng ứng dụng rộng hơn. Particle filter có thể áp dụng để ước lượng trạng thái của hệ thống trong cả trường hợp mô hình trạng thái là tuyến tính hoặc không tuyến tính, và nhiễu có thể có bất kỳ kiểu phân bố nào [7-8]. Nghiên cứu về ứng dụng Particle filter để ước lượng mức độ hư hỏng và dự đoán tuổi thọ thiết bị khi mà tình trạng thiết bị được giám sát bởi một cảm biến cũng bị hư hỏng theo thời gian vẫn còn hạn chế. Do đó, trong nghiên cứu

¹ The University of Danang – University of Science and Technology, Vietnam (Dinh Duc Hanh, Tao Quang Bang)

này, nhóm tác giả áp dụng Particle filter để ước lượng trạng thái hư hỏng của thiết bị chính, có xét đến sự hư hỏng của cảm biến giám sát tình trạng.

2. Mô hình hoá quá trình hư hỏng và ước lượng trạng thái của hệ thống

Đối tượng nghiên cứu là thiết bị trải qua quá trình hư hỏng dần dần và liên tục, quá trình hư hỏng này có thể dẫn đến những sự cố hư hỏng đột ngột. Quá trình hư hỏng này có thể là quá trình mài mòn cơ học, ăn mòn hoá học, hay là quá trình phát triển của vết nứt, v.v. [9]. Quá trình hư hỏng của thiết bị phát triển một cách liên tục và ngẫu nhiên. Do đó, mức độ hư hỏng của thiết bị theo thời gian được biểu diễn thông qua biến ngẫu nhiên $X(t)$. Thiết bị được xem là hư hỏng khi mức độ hư hỏng vượt ngưỡng hư hỏng (ký hiệu là L), tức là $X(t) > L$. Thời điểm mức độ hư hỏng vượt ngưỡng hư hỏng được gọi là thời điểm hư hỏng, ký hiệu là T_f .

2.1. Mô hình hoá quá trình hư hỏng của thiết bị

Có nhiều mô hình đã được đề xuất để mô hình hoá quá trình hư hỏng của thiết bị, như là mô hình chuỗi Markov [9], mô hình gama [10], và mô hình Wiener [11]. Trong đó, mô hình Wiener là phổ biến hơn cả. Mô hình Wiener mô tả quá trình hư hỏng không đơn điệu, với nhiều có kiểu phân bố chuẩn Gaussian. Mô hình này phù hợp để mô tả quá trình hư hỏng mà tình trạng hư hỏng được kiểm tra bởi các cảm biến có nhiễu. Mô hình Wiener đã được áp dụng rất phổ biến cả trong nghiên cứu và thực tiễn [12]. Theo đó, quá trình hư hỏng theo thời gian của thiết bị $X(t)$ được mô tả như sau:

$$X(t) = x_0 + \mu \cdot t + \sigma \cdot B(t) \quad (1)$$

Trong đó, x_0 là mức độ hư hỏng tại thời điểm $t = 0$; μ và σ là tốc độ và độ biến động của quá trình hư hỏng. Giả sử rằng, giá trị của μ và σ là biết trước. Trong thực tế, giá trị của μ và σ có thể được ước lượng từ dữ liệu quá trình hư hỏng của thiết bị trong quá khứ bằng các phương pháp như: ước lượng hợp lý tối đa, bình phương tối thiểu, v.v. [13]; $B(t)$ là chuyển động Brownian chuẩn, $B(t)$ tuân theo phân bố chuẩn với kỳ vọng bằng không và phương sai bằng t , tức là $B(t) \sim N(0, t)$. Hình 1 minh hoạ quá trình hư hỏng của thiết bị với các tham số $x_0 = 2,5$; $\mu = 1,5$ và $\sigma = 1,2$.

Do đó, mức độ hư hỏng của thiết bị, $X(t)$ tuân theo phân bố chuẩn với kỳ vọng $x_0 + \mu \cdot t$ và phương sai $\sigma^2 t$. Hàm mật độ xác suất của $X(t)$ như sau:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi t}} \exp\left(-\frac{1}{2}\left(\frac{x-(x_0+\mu t)}{\sigma\sqrt{t}}\right)^2\right) \quad (2)$$

Thời điểm hư hỏng xảy ra, tức là thời điểm mà mức độ hư hỏng vượt ngưỡng hư hỏng được xác định bởi:

$$T_f = \inf\{t: X(t) \geq L | x_0 \leq L\} \quad (3)$$

T_f tuân theo phân bố chuẩn nghịch đảo (inverse Gaussian distribution), với hàm mật độ xác suất (pdf) và hàm phân phối xác suất tích lũy (cdf) được cho bởi:

$$f_{T_f}(t) = \frac{L-x_0}{\sqrt{2\pi\sigma^2 t^3}} \exp\left(-\frac{(L-(x_0+\mu t))^2}{2\sigma^2 t}\right) \quad (4)$$

$$F_{T_f}(t) = 1 - \Phi\left(\frac{L-\mu t}{\sigma\sqrt{t}}\right) + \exp\left(\frac{2\mu(L-x_0)}{\sigma^2}\right) \Phi\left(\frac{-L-\mu t}{\sigma\sqrt{t}}\right) \quad (5)$$

Mức độ hư hỏng của thiết bị được định kỳ giám sát bởi một cảm biến tại $t_k = k \cdot \Delta T$ ($k = 1, 2, \dots$), ΔT được gọi là

chu kỳ giám sát. Tuy nhiên, do những yếu tố về môi trường, cũng như quá trình hoạt động, cảm biến cũng bị hư hỏng theo thời gian. Do đó, giá trị đo được bởi cảm biến có sai số. Trong mục tiếp theo, bài báo sẽ trình bày mô hình hoá quá trình hư hỏng của cảm biến, ảnh hưởng của nó đến độ chính xác của dữ liệu đo và kỹ thuật ước lượng mức độ hư hỏng của thiết bị dựa trên dữ liệu đo bởi cảm biến.



Hình 1. Quá trình hư hỏng của thiết bị [2]

2.2. Mô hình hoá quá trình hư hỏng của cảm biến và ảnh hưởng của nó

Mức độ hư hỏng của thiết bị được giám sát bởi một cảm biến. Lưu ý rằng, trong nghiên cứu này chỉ xét trường hợp chỉ dùng một cảm biến để giám sát mức độ hư hỏng của thiết bị. Trong trường hợp sử dụng nhiều cảm biến, cần phải xây dựng chỉ số tổng hợp biểu diễn mức độ hư hỏng của thiết bị dựa trên dữ liệu đo từ các cảm biến. Bạn đọc quan tâm đến trường hợp sử dụng nhiều cảm biến có thể tìm hiểu trong nghiên cứu [15].

Trong quá trình hoạt động, cảm biến cũng dần hư hỏng theo thời gian. Mức độ hư hỏng của cảm biến được xác định bởi sai số của dữ liệu đo, tức là sự sai khác giữa giá trị cho bởi cảm biến và mức độ hư hỏng thực tế của thiết bị. Tương tự thiết bị chính, quá trình hư hỏng của cảm biến cũng được mô hình hoá bởi mô hình Wiener.

$$S(t) = s_0 + \eta \cdot t + \zeta \cdot B(t) \quad (6)$$

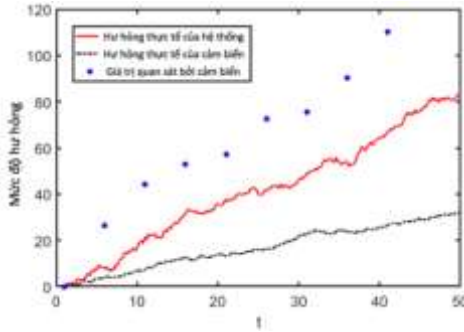
Trong đó, $S(t)$ là mức độ hư hỏng của cảm biến tại thời điểm t ; η và ζ là tốc độ và độ biến động của quá trình hư hỏng. Tương tự, η và ζ có thể được xác định dựa vào dữ liệu hư hỏng trong quá khứ của cảm biến. Giữ liệu hư hỏng của cảm biến có thể được xác định bằng cách so sánh với một cảm biến hoàn toàn mới, hoặc một thiết bị chuẩn mà biết rõ mức độ hư hỏng. Dựa trên dữ liệu hư hỏng trong quá khứ, giá trị của η và ζ có thể ước lượng được bằng nhiều phương pháp như: ước lượng hợp lý tối đa, bình phương tối thiểu, v.v. Chi tiết về phương pháp ước lượng giá trị các tham số này có thể tham khảo trong [14].

Gọi $Y(t)$, $t \geq 0$ là dữ liệu được chỉ thị bởi cảm biến tại thời điểm t . $Y(t)$ là sự kết hợp của 3 yếu tố: (1) mức độ hư hỏng của thiết bị, (2) mức độ hư hỏng của bản thân cảm biến và (3) nhiễu do môi trường. Tổng hợp ảnh hưởng sự hư hỏng của thiết bị và cảm biến, dữ liệu đo bởi cảm biến được xác định bởi:

$$Y(t) = X(t) + S(t) + \varepsilon(t) \quad (7)$$

Trong đó, $\varepsilon(t)$ là nhiễu do sự thay đổi của môi trường. $\varepsilon(t)$ tuân theo phân bố chuẩn với kỳ vọng bằng không và phương sai v^2 , tức là $\varepsilon(t) \sim N(0, v^2)$. Hình 2 biểu diễn dữ

liệu đo bởi cảm biến, mức độ hư hỏng thực tế của thiết bị và cảm biến. Nó cho thấy, giá trị hiển thị bởi cảm biến khác so với mức độ hư hỏng thực tế của thiết bị. Ở mục tiếp theo, Particle filter được sử dụng để ước lượng mức độ hư hỏng của thiết bị dựa trên dữ liệu đo bởi cảm biến.



Hình 2. Minh họa sự sai khác dữ liệu đo bởi cảm biến và mức độ hư hỏng thực tế của thiết bị.

2.3. Ứng dụng Particle filter để ước lượng mức độ hư hỏng và dự đoán tuổi thọ của thiết bị

Dữ liệu đo được bởi cảm biến là tổng hợp của 3 yếu tố: (1) mức độ hư hỏng của thiết bị, (2) mức độ hư hỏng của cảm biến và (3) nhiễu của quá trình đo. Do đó, cần ước lượng mức độ hư hỏng của thiết bị dựa trên dữ liệu đo của cảm biến. Với mục đích này, Particle filter được áp dụng. Particle filter là một bộ lọc Bayesian, tức là trạng thái của hệ thống được ước lượng sử dụng lý thuyết Bayesian. Nó cho phép ước lượng một trạng thái bằng cách kết một mô hình thống kê cho một phép đo với xác suất của trạng thái trước đó nhờ sử dụng lý thuyết Bayesian.

2.3.1. Particle filter để ước lượng mức độ hư hỏng của thiết bị

Về cơ bản, Particle filter gồm 3 bước như sau.

• Bước 1 - Xác định mô hình trạng thái

Gọi $s_k = S(t_k)$ and $x_k = X(t_k)$ là mức độ hư hỏng của cảm biến và của thiết bị tại thời điểm t_k . Gọi, $X_{1:k} = \{x_1, x_2, \dots, x_k\}$ và $S_{1:k} = \{s_1, s_2, \dots, s_k\}$ là tập hợp dữ liệu mức độ hư hỏng của thiết bị và cảm biến tới thời điểm t_k . Mức độ hư hỏng thực tế của thiết bị bị ảnh hưởng bởi sự hư hỏng của cảm biến và nhiễu của phép đo, và nó có thể được ước lượng dựa vào dữ liệu đo được bởi cảm biến tới thời điểm t_k , $Y_{1:k} = \{y_1, y_2, \dots, y_k\}$. Mô hình không gian trạng thái được xác định bởi:

$$\begin{cases} x_k = x_{k-1} + \mu(t_k - t_{k-1}) + u_k \\ s_k = s_{k-1} + \eta(t_k - t_{k-1}) + v_k \\ y_k = x_k + s_k + \varepsilon_k \end{cases} \quad (8)$$

Trong đó, $u_k = \sigma[B(k) - B(k-1)]$ và $v_k = \zeta[B(k) - B(k-1)]$. $\{u_k, k \geq 0\}$, $\{v_k, k \geq 0\}$, $\{\varepsilon_k, k \geq 0\}$ tuân theo phân bố chuẩn, tức là $u_k \sim N(0, \sigma^2(t_k - t_{k-1}))$, $v_k \sim N(0, \zeta^2(t_k - t_{k-1}))$, và $\varepsilon_k \sim N(0, v^2)$.

Để áp dụng Particle filter, mô hình không gian trạng thái được viết lại như sau:

$$\begin{cases} z_k = A \cdot z_{k-1} + B_k + w_k \\ y_k = H \cdot z_k + \varepsilon_k \end{cases} \quad (9)$$

Trong đó, $z_k = \begin{bmatrix} x_k \\ s_k \end{bmatrix}$, $A = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$,

$$B_k = \begin{bmatrix} \mu(t_k - t_{k-1}) \\ \eta(t_k - t_{k-1}) \end{bmatrix}, \quad H = [1 \quad 1], \quad w_k \sim N(0, Q_k), \quad \text{với}$$

$$Q_k = \begin{bmatrix} \sigma^2(t_k - t_{k-1}) & 0 \\ 0 & \zeta^2(t_k - t_{k-1}) \end{bmatrix}.$$

• Bước 2 - Dự đoán

Ở bước này, mô hình trạng thái biểu diễn sự thay đổi của trạng thái của hệ thống được kết hợp với phân bố xác suất tiên nghiệm ở bước trước đó, $p(z_{k-1}|y_{1:k-1})$. Áp dụng phương trình Chapman-Kolmogorov, trạng thái tiên nghiệm, tức là dự đoán tốt nhất tại thời điểm k dựa trên dữ liệu đo được cập nhật đến thời điểm $k-1$, ký hiệu là $p(z_k|y_{1:k-1})$, được ước lượng dựa trên phân bố xác suất của trạng thái trước đó $p(z_{k-1}|y_{1:k-1})$.

$$p(z_k|y_{1:k-1}) = \int p(z_k|z_{k-1}) \cdot p(z_{k-1}|y_{1:k-1}) dz_{k-1} \quad (10)$$

• Bước 3 - Cập nhật

Ở bước này, lý thuyết Bayesian được áp dụng, sử dụng dữ liệu đo được cập nhật đến thời điểm k , y_k để ước lượng trạng thái hệ thống. Ước lượng trước đó trong Công thức (11) được cập nhật bởi $p(z_k|y_{1:k})$ với giá trị đo được y_k tại thời điểm k .

$$p(z_k|y_{1:k}) = \frac{p(y_k|z_k) \cdot p(z_k|y_{1:k-1})}{p(y_k|y_{1:k-1})} \quad (11)$$

$p(z_k|y_{1:k})$ biểu diễn xác suất có điều kiện của trạng thái của hệ thống khi biết $p(z_k|y_{1:k-1}) \cdot p(y_k|y_{1:k-1})$ là xác suất có điều kiện của phép đo.

$$p(y_k|y_{1:k-1}) = \int p(y_k|z_k) \cdot p(z_k|y_{1:k-1}) dz_k \quad (12)$$

Các bước dự đoán và cập nhật được thực hiện đệ quy để ước lượng trạng thái của hệ thống.

Phương trình (10) và (12) chỉ có thể được giải nếu đáp ứng những điều kiện như là mô hình tuyến tính với nhiễu có kiểu phân bố chuẩn. Tuy nhiên, Particle filter xấp xỉ hàm mật độ xác suất bằng một hàm mật độ xác suất rời rạc, do đó nó cho phép áp dụng cho nhiều dạng mô hình. Điều này có thể đạt được bằng cách sử dụng một tập hợp các mẫu ngẫu nhiên có trọng số tương ứng để biểu diễn hàm mật độ xác suất. Chi tiết như sau:

N_s particle được tạo với trạng thái ban đầu z_0 . Trong mỗi vòng lặp các particle đại diện cho trạng thái hiện tại, ký hiệu là $z_{k|k-1}^i$, $i = 1, 2, \dots, N_s$ được xác định bằng cách sử dụng công thức (9) với trọng số của particle được cập nhật bởi:

$$w_k = w_{k-1} \frac{p(y_k|z_k) \cdot p(z_k|z_{k-1})}{q(z_k|z_{k-1}, y_k)} \quad (13)$$

Trong đó, $q(z_k|z_{0:k-1}, y_{1:k})$ là hàm mật độ quan trọng. Thông thường, hàm này có thể lấy là $p(z_k|z_{k-1})$; $p(y_k|z_k)$ là hàm mật độ dự đoán trạng thái hiện tại. Hàm mật độ trạng thái tiếp theo $p(z_k|y_{1:k})$ được xấp xỉ bởi các particle với hàm khối xác suất rời rạc trong công thức (14) với các particles có trọng số $\tilde{w}_k^i = \frac{w_k^i}{\sum_{j=1}^{N_s} w_k^j}$.

$$p(z_k|y_{1:k}) = \sum_{i=1}^{N_s} \tilde{w}_k^i \delta(z_k - z_k^i) \quad (14)$$

$\{w_k^i, z_k^i\}_{i=1}^{N_s}$ là tập hợp N_s mẫu và trọng số tương ứng. Mỗi mẫu z_k^i đại diện cho khả năng xuất hiện của một trạng thái. Trọng số w_k^i thể hiện mức độ quan trọng của particle đó

trong tổng N_s mẫu z_k^i và $\sum_{i=1}^{N_s} w_k^i = 1$. Mẫu có trọng số lớn được hiểu là gần trạng thái thực của hệ thống hơn những biến có trọng số thấp. $\delta(\cdot)$ là hàm delta Diract. Hàm delta Diract $\delta(x)$ nhận giá trị bằng không tại mọi điểm khác x . Bằng cách tăng số lượng particle lên, phương pháp ước lượng này có thể tiệm cận nghiệm chính xác. Khi đó, ước lượng trạng thái của hệ thống được xấp xỉ bởi:

$$\hat{z}_k = \int z_k \cdot p(z_k | y_{1:k}) dz_k$$

$$= \frac{1}{N_s} \cdot \sum_{k=1}^{N_s} \int z_k \cdot \delta(z_k) \cdot dz_k = \frac{1}{N_s} \sum_{k=1}^{N_s} \hat{z}_k^i \quad (15)$$

2.3.2. Dự đoán tuổi thọ của thiết bị

Sử dụng ước lượng trạng thái hiện tại, và cập nhật các tham số của mô hình hư hỏng của thiết bị, trạng thái trong tương lai của thiết bị được dự đoán bằng phương trình tích phân đệ quy sau:

$$p(z_{k+p} | y_{1:k}) = \int p(z_k | y_{0:k}) \prod_{j=k+1}^{k+p} p(z_j | x_{k-1}) dx_{k:k+p-1}$$

$$= \sum_{i=1}^{N_s} w_{k+p-1}^i \cdot p(z_{k+p} | z_{k+p-1}) \quad (16)$$

Thời điểm hư hỏng của thiết bị (RUL) được ước lượng bởi:

$$p(RUL | y_{1:k}) = \sum_{i=1}^{N_s} \tilde{w}_k^i \delta(RUL - RUL^i) \quad (17)$$

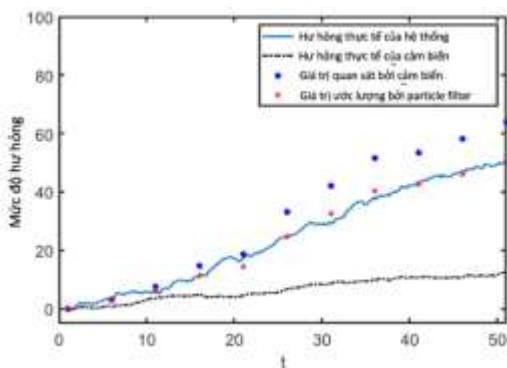
3. Kết quả nghiên cứu

Trong mục này, một ví dụ áp dụng để chứng minh tính hiệu quả và khả năng áp dụng của Particle filter trong ước lượng trạng thái hư hỏng và dự đoán tuổi thọ của thiết bị. Hệ thống có các tham số được cho trong Bảng 1.

Bảng 1. Tham số của hệ thống

Tham số	μ	σ^2	v^2	L	η	ζ
Giá trị	1,2	1,0	2	70	0,3	0,4

Hình 4 biểu diễn ứng dụng Particle filter trong ước lượng mức độ hư hỏng của thiết bị với giá trị các tham số của mô hình được cho trong Bảng 1.



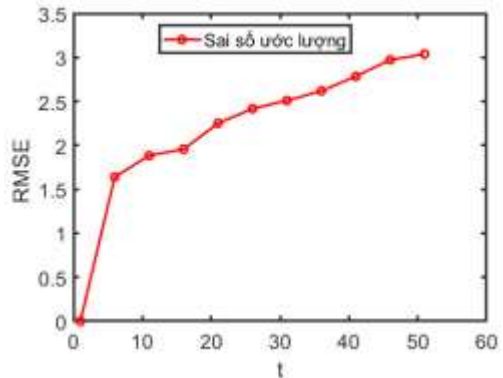
Hình 4. Ứng dụng Particle filter trong ước lượng mức độ hư hỏng của thiết bị

Kết quả cho thấy, Particle filter đã giúp cung cấp chính xác hơn thông tin mức độ hư hỏng của thiết bị.

Để đánh giá chính xác hơn hiệu quả của việc sử dụng Particle filter trong ước lượng trạng thái hư hỏng của thiết bị, thông số Sai số ước lượng trung bình (RMSE - Root Mean Square Error) được dùng để đánh giá. Trong đó, RMSE được xác định như sau:

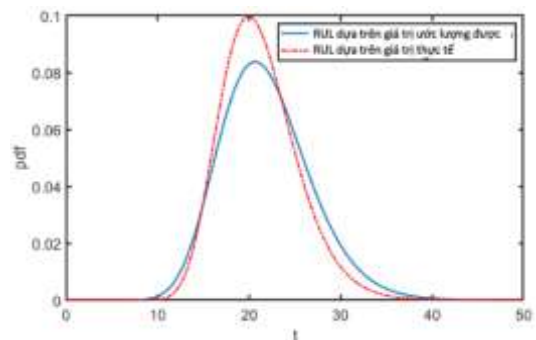
$$RMSE = \sqrt{\frac{\sum (\hat{x}_{k|k} - x_k)^2}{N}} \quad (18)$$

Trong đó, x_k là mức độ hư hỏng thực tế và $\hat{x}_{k|k}$ là mức độ hư hỏng ước lượng được bởi Particle filter tại thời điểm t_k , N là tổng số lần mô phỏng (N=2000 trong ví dụ này). Hình 5 biểu diễn sai số ước lượng trung bình khi sử dụng Particle filter để ước lượng trạng thái hư hỏng thiết bị. Kết quả cho thấy, particle filter có giúp ước lượng trạng thái hư hỏng của thiết bị gần với giá trị thực tế.



Hình 5. Sai số ước lượng trung bình của Particle filter

Hình 6 biểu diễn hàm mật độ xác suất của tuổi thọ của thiết bị dựa trên giá trị ước lượng được bởi Particle filter. Kết quả cho thấy, giá trị dự đoán tuổi thọ của thiết bị dựa trên dữ liệu ước lượng bởi Particle filter cho kết quả gần đúng với giá trị dự đoán dựa trên mức độ hư hỏng thực tế.



Hình 6. Dự đoán tuổi thọ của thiết bị

4. Kết luận

Nghiên cứu này trình bày ứng dụng của Particle filter trong ước lượng mức độ hư hỏng và dự đoán tuổi thọ của thiết bị biết rằng thông tin về mức độ hư hỏng của thiết bị được giám sát bởi một cảm biến cũng bị hư hỏng. Kết quả cho thấy, Particle filter đã giúp cung cấp chính xác hơn thông tin mức độ hư hỏng của thiết bị. Mặc dù, Particle filter đã giúp nâng cao độ chính xác của dữ liệu giám sát mức độ hư hỏng của thiết bị, tuy nhiên vì Particle filter ước lượng giá trị kỳ vọng của mức độ hư hỏng của thiết bị dựa trên dữ liệu có chứa nhiễu, do đó sự sai khác giữa giá trị ước lượng được bởi Particle filter và giá trị thực là điều không thể tránh khỏi. Vì vậy, ra quyết định bảo trì dựa hoàn toàn vào giá trị hư hỏng ước lượng được bởi Particle filter có thể không chính xác. Nghiên cứu tiếp theo của nhóm tác giả sẽ xây dựng chính sách bảo trì để hạn chế ảnh hưởng của sai số ước lượng này.

Lời cảm ơn: TS. Đinh Đức Hạnh được tài trợ bởi Chương trình học bổng sau tiến sĩ trong nước của Quỹ Đổi mới sáng tạo Vingroup (VINIF), mã số VINIF.2023.STS.07.

TÀI LIỆU THAM KHẢO

- [1] D. J. Bram and P. A. Scarf, "A review on maintenance optimization", *European journal of operational research*, vol. 285, no. 3, pp. 805-824, 2020.
- [2] Đ. Đ. Hanh., N. P. T. Nhan, T. Q. Bang, and N. L. Giang, "Predictive opportunistic maintenance policy for multi-component system with structural and economic dependences", *Journal of science and technology - The university of Da Nang*, vol. 21. no. 1, pp. 1-6, 2023.
- [3] N. K. Anh, D. Phuc, and A. Grall, "Multi-level predictive maintenance for multi-component systems", *Reliability engineering & system safety*, vol. 144, pp. 83-94, 2015.
- [4] T. Zonta, C. A. Costa, R. R. Righi, M. J. Lima, E. S. Trindade, and G. P. Li, "Predictive maintenance in the Industry 4.0: A systematic literature review", *Computers & Industrial Engineering*, vol. 150, pp. 106889, 2020.
- [5] D. D. Hanh, "Opportunistic predictive maintenance for multi-component systems with multiple dependences", Ph.D. dissertation, Université de Lorraine, 2021.
- [6] B. Liu, P. Do, B. Iung, and M. Xie, "Stochastic filtering approach for condition-based maintenance considering sensor degradation", *IEEE Transactions on Automation Science and Engineering*, vol. 17. no. 1, pp. 177-190, 2019.
- [7] R. Xiong, F. Sun, Z. Chen, and H. He, "A data-driven multi-scale extended Kalman filtering based parameter and state estimation approach of lithium-ion polymer battery in electric vehicles", *Applied energy*, vol. 113, pp. 463-476, 2014.
- [8] Y. H. Lin and X.L. Jiao, "Adaptive kernel auxiliary particle filter method for degradation state estimation", *Reliability Engineering & System Safety*, vol. 211, pp. 107562, 2021.
- [9] H. Shi and J. Zeng, "Real-time prediction of remaining useful life and preventive opportunistic maintenance strategy for multi-component systems considering stochastic dependence", *Computers & Industrial Engineering*, vol. 93, pp. 192-204, 2016.
- [10] N. T. P. Khanh, M. Fouladirad, and A. Grall, "Model selection for degradation modeling and prognosis with health monitoring data", *Reliability Engineering & System Safety*, vol. 169, pp. 105-116, 2018.
- [11] C. Letot, P. Dehombreux, E. Rivière-Lorphèvre, G. Fleurquin, and A. Lesage, "A degradation model for maintenance improvement in respect of cost and availability", *Journal of Quality in Maintenance Engineering*, vol. 21, no.1, pp. 55-69, 2015.
- [12] W. Wang, M. Carr, W. Xu, and K. Kobbaçy, "A model for residual life prediction based on Brownian motion with an adaptive drift", *Microelectronics Reliability*, vol. 51, no. 2, pp. 285-293, 2011.
- [13] J. Li, B. Jing, H.D. Dai, X. X. Jiao, and X. D. Liu, "Remaining useful life prediction based on variation coefficient consistency test of Wiener process", *Chinese journal of Aeronautics*, vol. 31, no. 1, pp. 107-116, 2018.
- [14] X. S. Si, W. Wang, C. H. Hu, M. Y. Chen, and D. H. Zhou, "A Wiener-process-based degradation model with a recursive filter algorithm for remaining useful life estimation", *Mechanical Systems and Signal Processing*, vol. 35, no. 1, pp. 219-237, 2013.
- [15] C. Song and K. Liu, "Statistical degradation modeling and prognostics of multiple sensor signals via data fusion: A composite health index approach", *IISE Transactions*, vol. 50, no. 10, pp. 853-867, 2018.

PHỤ LỤC

Ứng dụng particle filter ước lượng trạng thái hệ thống khi quá trình hư hỏng của thiết bị và cảm biến tuân theo gamma process

Gamma process là một quá trình ngẫu nhiên đơn điệu tăng với mức tăng độc lập và không âm tuân theo phân bố gamma. Gamma process thường được dùng để mô tả quá trình hư hỏng gây ra bởi quá trình mài mòn, ăn mòn, v.v.

Giả sử quá trình hư hỏng của thiết bị tuân theo gamma process, mức độ hư hỏng của thiết bị tại thời điểm $t, t > s > 0$ được biểu diễn như sau:

$$X(t) = X(s) + \Delta X(t-s) \quad (A.1)$$

Trong đó, $X(s)$ là mức độ hư hỏng tại thời điểm s , $\Delta X(t-s)$ là mức độ hư hỏng tăng thêm trong khoảng thời gian $t-s$. $\Delta X(t-s)$ tuân theo kiểu phân bố gamma với tham số hình dạng $\alpha_X(t-s)$ và tham số tỉ lệ β_X , hàm mật độ xác suất của nó như sau:

$$f_{\alpha_X(t-s), \beta_X}(x) = \frac{1}{\Gamma[\alpha_X(t-s)]} \beta_X^{\alpha_X(t-s)} x^{\alpha_X(t-s)-1} e^{-\beta_X x} \quad (A.2)$$

Trong đó, $\Gamma[t] = \int_0^\infty u^{t-1} \exp(-u) du$ là hàm Euler gamma.

Tương tự, quá trình hư hỏng của cảm biến được mô tả bởi:

$$S(t) = S(s) + \Delta S(t-s) + \alpha \Delta X(t-s) \quad (A.3)$$

Trong đó, $\Delta S(t-s)$ là mức độ hư hỏng tăng thêm trong khoảng thời gian $t-s$. $\Delta S(t-s)$ tuân theo kiểu phân bố gamma với tham số hình dạng $\alpha_S(t-s)$ và tham số tỉ lệ β_S , hàm mật độ xác suất của nó như sau:

$$f_{\alpha_S(t-s), \beta_S}(x) = \frac{1}{\Gamma[\alpha_S(t-s)]} \beta_S^{\alpha_S(t-s)} x^{\alpha_S(t-s)-1} e^{-\beta_S x} \quad (A.4)$$

Khi đó, dữ liệu đo được bởi cảm biến sẽ là:

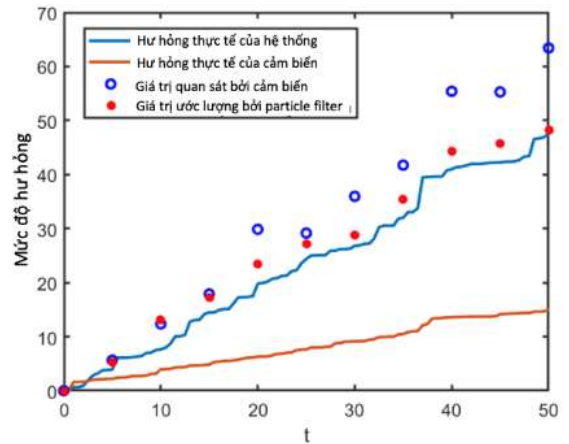
$$Y(t) = X(t) + S(t) + \varepsilon(t) \quad (A.5)$$

Với $\varepsilon(t) = \varepsilon_0 \sim N(0, v^2)$. Giả sử các tham số của mô hình được cho như trong Bảng A.1.

Bảng A.1. Tham số của mô hình

α_X	β_X	α_S	β_S	v
1.0	1.2	0.5	0.6	2

Hình A.1 biểu diễn ứng dụng Particle filter trong ước lượng mức độ hư hỏng của hệ thống khi quá trình hư hỏng của hệ thống và cảm biến tuân theo gamma process. Kết quả cho thấy, Particle filter hoạt động tốt trong trường hợp quá trình hư hỏng của hệ thống và cảm biến tuân theo gamma process.



Hình A.1. Ứng dụng Particle filter để ước lượng trạng thái hệ thống với gamma process